

Umělá inteligence v primární péči: Od redukce dimenzionality po klinické rozhodování a časovou úsporu

Michal Mačák

Všeobecný praktický lékař, Medikatze, s. r. o., Litovel

Přehledový článek shrnuje principy umělé inteligence a jejího využití v primární péči se zaměřením na redukci dimenzionality dat a implementaci velkých jazykových modelů v klinickém rozhodování z pohledu všeobecného praktického lékaře. Článek demonstruje, jak moderní algoritmy založené na latentních reprezentacích a hlubokém učení napomáhají zefektivnit diagnostiku, upřesnit diagnózu a usnadnit administrativní úkony, přičemž respektují klinickou zkušenost praktického lékaře.

Klíčová slova: umělá inteligence, jazykové modely, LLM, prompt, transformer, primární péče.

Artificial intelligence in primary care: From dimensionality reduction to clinical decision-making and time efficiency

This review summarizes the principles of applying artificial intelligence (in primary care, focusing on dimensionality reduction and the integration of large language models in clinical decision-making. The article demonstrates how modern algorithms based on latent representations and deep learning contribute to more efficient diagnostics, refined diagnosis, and streamlined administrative processes, all while complementing the clinical expertise of practicing physicians.

Key words: artificial intelligence, language models, LLM, prompt, transformer, primary care.

Úvod

Umělá inteligence (AI – Artificial Intelligence) je kontroverzním tématem aktuální doby. Někteří ji obdivují, zatímco jiní zaujímají velmi skeptický postoj. Stejně tak AI mezi lékaři vzbuzuje nadšení u těch, kdo vidí její potenciál pro revoluci v diagnostice, administrativě a správě patientských dat, ale i obavy z dehumanizace, možných chyb, kyberbezpečnosti a generování nepřesné či zavádějící informace. Tyto obavy často plynou z nedostatečné informovanosti a nízké transparentnosti této technologie.

V prostředí medicíny prvního kontaktu, kde je třeba rychle reagovat na širokou škálu zdravotních stavů, umožňuje AI redukovat komplexnost vstupních informací prostřednictvím metod redukce dimenzionality jako jednoho ze základních pilířů inteligence (1), čímž se zefektivňuje pracovní tok a podporuje personalizované klinické rozhodování. Pro efektivní využití umělé inteligence v klinické praxi je vhodné porozumět jejím základním principům. Není přitom nezbytné mít vzdělání v informatice ani hluboce rozumět všem algoritmům strojového učení.


Avšak určitá základní znalost těchto principů je klíčová pro bezpečné a účinné začlenění AI do medicínského prostředí. Základní znalost lékařů v neurovědách, neuroanatomii a neurofyziologii získaná při studiu je výhodou při porozumění těmto základním principům, na nichž jsou postaveny moderní architektury umělé inteligence.

Redukce dimenzionality, latentní reprezentace a generovaný výstup

Základními principy inteligence, pro názornost a potřeby tohoto článku definované jednoduše jako schopnost dosáhnout cíle, jsou:

- redukce dimenzionality
- prediktivní abstraktní model světa
- odměna za minimalizaci predikční chyby (2) (Obr. 1).

Redukce dimenzionality, tedy ztrátová komprese informací, umožňuje extrahovat podstatné znaky z rozsáhlých datových souborů. K to-

Obr. 1. *Pilíře inteligence a učení*

mu strojům slouží mnoho technik. Za jednou z nich stojí geniální nápad českého vědce Tomáše Mikolova, a to převést slova na vektory charakterizované tisíci souřadnicemi v multidimenzionálním kyberprostoru (3). Vektory zachycují sémantické vztahy mezi slovy, takže podobná slova se nacházejí blízko sebe ve vektorovém prostoru, to poskytuje strojům kontext a strukturu textových dat a tím – jednoduše řečeno – chápat význam. Obrazová data jsou zase pomocí konvoluce komprimována na takzvané mapy rysů (například rys definující hranu), jež pak vystihují základní esenci obrazu. Cílem je u všech typů dat získat kompaktní reprezentaci původních informací pro jejich efektivnější zpracování.

Lidský mozek zpracovává multidimenzionální senzorické vstupy pomocí komplexních neuronových sítí, které využívají kombinaci heuristik, empirických zkušeností a intuice – tedy schopnosti rozpoznat podstatné rysy bez vědomé analýzy. Tento proces probíhá v rámci prediktivního abstraktního modelu okolního světa, kde vyšší kognitivní úrovně generují abstraktní předpovědi, které jsou porovnávány s reálnými daty senzorických vstupů (4).

Mozek zároveň interpretuje výsledky těchto procesů prostřednictvím přirozeného jazyka – univerzálního nástroje k reprezentaci a sdílení vnitřních modelů. Právě přirozený jazyk, převedený do vektorových reprezentací, se ukázal jako mimořádně efektivní pro architekturu umělé inteligence.

Náš mozek se snaží minimalizovat predikční chybu, což představuje adaptační mechanismus, jehož neurofyziologickým korelátem je dopaminová signalizace (dopamin jako signál „lepšího než očekávaného“). To je základem posilovaného učení (RL – reinforcement learning). V analogii s lidským učením byl v posilovaném učení strojů nahrazen dopamin signálem odměny, případně lidskou zpětnou vazbou, což umožňuje

během trénování těchto modelů přizpůsobit výstupy AI k praktickým a lidsky relevantním cílům.

Technické řešení architektury moderních generativních jazykových modelů označujeme jako transformer. Ten slouží k analýze a generování sekvencí, jako je text, dnes už i obraz, video nebo zvuk. Během tréninku na gigantických datových souborech transformer extrahuje jejich esenci, vytvoří si abstraktní model světa či latentní (pro nás skrytou) reprezentaci světa – jakousi prediktivní pravděpodobnostní mapu souvislostí, statistické vzorce a vztahy korigované lidskou zpětnou vazbou. Takto se model nastaví. Zde je dobře patrný rozdíl, kdy v lidském mozku tento proces běží neustále, naopak jazykový model strojů je takto nastaven při trénování jednou. Ale i to se už daří korigovat například napojením na internetové vyhledávače, případně novým přetrénováním celého transformera po určitém čase. Pak přichází již naše interakce s tímto naučeným jazykovým modelem. Pro názornost dále zmiňuji generující proces textu, který je pro primární péči relevantnější než obraz či jiná data. Namísto trénovacích vstupních dat do nastaveného naučeného modelu vstoupí naše nová informace, výzva, otázka – tzv. PROMPT, který spustí interní generativní proces. Ve skutečnosti model jen napodobuje jazykové a logické vzorce, které se naučil. Výsledkem je v případě textového výstupu předpověď následujícího slova, které navazuje na prompt. Toto slovo je vybráno z vypočtené škály pravděpodobností všech slov metodou tzv. samplingu, kdy každý výrobce různou mírou určuje, zda bude výstup spíše kreativní, nebo přesný deterministický. Na původní prompt se tedy napojuje generované slovo, tento celý text je pak novým vstupem a celý proces generuje další slovo a tak dále, dokud není generovaná smysluplná informace. Výsledkem je komunikace, která se postupně přibližuje úrovni mezilidské interakce. Kritické myšlení je zde na místě, neboť generovaná data nejsou faktická tvrzení, ale spíše pravděpodobnostní odhad a takto je k nim potřeba přistupovat. Časté situace, kdy model generuje výstupy, které znějí přesvědčivě, ale jsou fakticky nesprávné, smyšlené nebo zavádějící, označujeme jako halucinace jazykových modelů. Ty jsou jádrem kritiky a obav ze zavádění těchto technologií v medicíně, kde i drobná nepřesnost může stát život. Kvalita našeho promptu zásadně určuje kvalitu odpovědi modelu. Zatímco lidé obvykle odpovídají přesně na jednoduché otázky, ale tápou u složitějších, jazykové modely typu transformer často fungují opačně – čím promyšlenější a strukturovanější je vstup, tím kvalitnější bývá odpověď. Odborně specifická terminologie umožňuje transformeru aktivovat vektorové reprezentace blízké relevantním zdrojům, čímž se zvyšuje přesnost a validita generovaných odpovědí. Naopak na neurčitý nebo banální dotaz mohou reagovat nepřesně či halucinací. Měli bychom také mít na paměti, že modely se učily na datech, jejichž validitu neznáme.

To, jakou základní roli má jazykový model v našem rozhovoru zaujmout, je dáno tzv. systémovým promptem, vstupní instrukcí, která není běžnému uživateli viditelná, ale zásadně ovlivňuje chování modelu. Může například obsahovat instrukce typu: „jsi asistent, odpovídej srozumitelně, zdvořile, buď nápomocný, eticky vyvážený, odpovídej maximálně v určitých počtech znaků“ a podobně. Tento úvodní kontext rámuje celou interakci – podobně jako když lékař ví, že právě mluví s pacientem, kolegou nebo dítětem, a podle toho

Tab. 1. Přehled nejpoužívanějších LLM na trhu – duben 2025

Název	Společnost	Země	Typ	Přednosti
ChatGPT	OpenAI	USA	LLM	Nejrozšířenější model, široké využití v různých oblastech
Gemini	Google DeepMind	USA	LLM	Integrace s Android a Google
Claude	Anthropic	USA	LLM	Důraz na bezpečnost a etické aspekty, vhodný pro citlivé aplikace
Grok	xAI	USA	LLM	Napojen na síť X (dříve Twitter), autentický a aktuální
LLaMA	Meta	USA	LLM	Integrace s Instagramem a Facebookem, dále pro výzkumné a vývojové účely (open-source)
Mistral	Mistral AI	Francie	LLM	Evropský zástupce, velmi rychlý (open-source)
Copilot	Microsoft	USA	využívá více LLM	Integrace do Microsoft 365, zaměřeno na produktivitu a kancelářské nástroje
Perplexity	Perplexity AI	USA	využívá více LLM	Kombinuje více LLM a efektivní vyhledávání s rešeršemi

volí jazyk i chování. Uživatel pak přidává vlastní uživatelský prompt, jež může dále celou konverzaci formovat požadovaným směrem, a které model zpracovává výše uvedeným způsobem. Prompty zadane uživatelem putují přes internet do výpočetních center, která tvoří rozsáhlé rackové servery stovky metrů dlouhé, často umístěné v podzemních datových komplexech v různých částech světa; právě tam dochází v transformeru k samotnému generování výstupu, který je poté v řádu sekund doručen zpět do našeho mobilního zařízení nebo počítače (Obr. 2). Tato komunikace pak přináší nápady a může dopomoci k stanovenému cíli.

Využití generativních modelů AI v primární péči a klinické rozhodování

Velké jazykové modely (Large Language Models dále jen LLM, viz tabulka 1), jako je například nejpoužívanější ChatGPT od firmy OpenAI, patří mezi nejpokročilejší aplikace AI. Jsou již multimodální, pracují s více typy dat. Zdravotnická dokumentace obsahuje převážně obrazová a textová data, která se přímo nabízí k tomuto zpracování (5).


Nejpočetnější věkovou skupinou (přes 30 %) využívající ChatGPT je věk 25–34 let. Tato věková skupina odpovídá většině mladých praktických lékařů ve specializační přípravě či krátce po atestaci. V Česku aktuálně přibývá přes 200 nových atestovaných praktiků pro dospělé ročně, což z této generace činí přirozené uživatele AI nástrojů v medicíně.

Ve známé randomizované studii z roku 2024, tedy z pohledu překotného vývoje AI starého data, bylo prokázáno, že integrace LLM

do diagnostického procesu vede k mírnému zlepšení diagnostického uvažování. Samotný jazykový model byl v diagnostice dokonce přesnější než lékaři rezidenti (6). Je vhodné zmínit, že lékaři často nebyli poučeni, s jakou entitou komunikují, nebyli školeni v promptování, jak se dnes tato komunikace označuje. V roce 2024 a začátkem roku 2025 proběhlo několik zahraničních studií v medicíně prvního kontaktu (Německo, Japonsko, USA, Velká Británie), většinou se jednalo o použití ChatGPT 4. Ten ještě neobsahoval aktivní funkce internetového vyhledávání, které dnes umožňují ověřování generovaných výstupů a citování konkrétních zdrojů. Současné generativní jazykové modely se od těch testovaných v dostupných studiích zásadně liší – jak úrovní porozumění, tak schopností pracovat s aktuálními daty. Vývoj postupuje natolik rychle, že i tento text bude pravděpodobně v blízké budoucnosti zastaralý, protože v rámci AI hovoříme i v jednotkách týdnů (7). I přesto starší LLM vedly ke snížení administrativy, kognitivního bias a potřeby času na pacienta. Autorovi tohoto článku v posledním roce AI prokazatelně ušetřila mnoho minut pracovního času denně. Na obzoru je například zavedení nové mezinárodní klasifikace nemocí MKN-11, kde může AI sehrát klíčovou roli při její hladké integraci do každodenního chodu zdravotnických zařízení.

Je evidentní, že při správné implementaci slouží LLM jako podpůrný nástroj, který optimalizuje pracovní tok a šetří cenný čas lékaře (8). V primární péči se rýsuje řada konkrétních využití (Tab. 2). Tento seznam není jistě konečný a další možnosti využití generativních modelů budou jistě přibývat. Z pochopitelných důvodů převládají obavy z implementace v diagnostických procesech, zatímco administrativní práce jsou ideální volbou k prvnímu seznámení se s AI nástroji. V posledních letech se jazykové modely etablovaly jako nástroje pro vedení konverzace za účelem zpracování informací – tzv. chatboty. Rok 2025 však přináší výrazný posun směrem k tzv. reasonerům neboli debatérům, tedy modelům schopným řetězit myšlenkové kroky a poskytovat strukturovanější a logicky navazující odpovědi. Následující vývoj směřuje k tzv. agentním systémům – autonomním modelům, které dokážou samostatně plánovat, rozhodovat a řešit komplexní úkoly bez nutnosti přímého řízení uživatelem.

S rostoucí autonomií těchto systémů však narůstá i odpovědnost za to, jakým způsobem jsou nasazovány v klinické praxi. O to důležitější je důsledně dbát na ochranu osobních údajů pacientů a jasně vymezit, k jakým datům mají jazykové modely – zejména ve formě agentních systémů – přístup. Každé jejich zapojení do pracovních procesů musí být pečlivě posouzeno z hlediska etiky, bezpečnosti a souladu s aktuální legislativou. To by nám však nemělo bránit v prozkoumávání potenciálu této fascinující technologie.

Obr. 2. Podzemní rackové servery, ilustrace vytvořená pomocí chatGPT

Tab. 2. Využití LLM v primární péči

Způsob využití	Konkrétní aplikace
Automatická dokumentace návštěv	Redukce administrativy, přepis z dikce nebo poznámek do strukturované formy (zatím problém s češtinou a dialekty u přepisu mluveného slova)
Generování lékařských zpráv, souhrny	Rychlejší zápis, racionalizace obsahu dekurzu a ambulantních zpráv, souhrny diagnóz
Shrnutí funkčního či jiného postižení pacienta na základě diagnóz a objektivního stavu (ČSSZ, soudy, policie, UP, lůžkový návrh, výpis ze zdravotní dokumentace, posudky, bolestné atd.)	Pomoc s vyplňováním složitých formulářů (modely lze nastavit k využití konkrétních metodik, sbírky zákonů a aktuálních doporučení jednotlivých institucí)
Tvorba edukativních materiálů a instrukcí pro pacienta	Personalizované materiály přizpůsobené porozumění daného pacienta
Odpovědi na on-line dotazy pacientů a přepis hovorů s voiceboty do dekurzu	Rychlé návrhy empatických odpovědí, snížení časové zátěže, budoucnost elektronických sestřiček
Personalizovaný překlad zdravotních informací do cizích jazyků	Uspornění komunikace s cizinci, vyšší dostupnost péče
Návrh diferenciální diagnostiky	Kognitivní amplifikátor lékaře
Interpretace klinických případů	Brainstorming u složitých či méně častých případů, nevysvětlitelných symptomů, částečná pomoc za mnohdy nedostupného specialistu
Posouzení terapeutického postupu	Porovnání vlastního terapeutického plánu s guidelines
Automatická detekce rizikových faktorů	Upozornění, identifikace a kvantifikace rizikovitosti pacienta, zařazení do dispenzárních skupin, návrh očkování, podnět k prevenci
Generování informovaných souhlasů	Zjednodušení složitých textů pro pacienta, vysvětlení rizik
Asistované kódování výkonů a diagnóz	Snad časem automatické vykazování výkonů, optimalizace kódování, méně chyb a přesnější statistika

Technické požadavky a integrace AI do ambulantních softwarů

Implementace jazykových modelů (LLM) a dalších nástrojů umělé inteligence v primární péči vyžaduje technické zázemí, které můžeme rozdělit na cloudová řešení (zpracování dat vzdáleně v datových centrech poskytovatelů AI) a lokální řešení (tzv. edge computing, kdy model běží přímo ve zdravotnickém zařízení)

Cloudová řešení, při kterých jsou data zpracovávána vzdáleně v externích datových centrech poskytovatelů AI, s sebou nesou zvýšené riziko z hlediska ochrany citlivých údajů. Přenos dat mimo zdravotnické zařízení totiž může vést k potenciálním problémům s datovou bezpečností, což vyžaduje důkladné zabezpečení a pečlivé posouzení souladu s platnou legislativou. Lokální řešení (edge computing), kde model běží přímo ve zdravotnickém zařízení, tuto nevýhodu minimalizují, avšak zatím nejsou v našem prostředí běžně dostupná. Aktuálně nejsou známy případy komerčního nebo národního řešení lokálního využívání LLM v českých soukromých ambulancích, protože jazykové modely velkých společností nejsou dosud dostupné jako lokální instalace a vzhledem k hardwarovým požadavkům zřejmě dlouho dostupné nebudou. Integrace cloudových technologií do běžně používaných ambulantních softwarů představuje v českých podmínkách značnou technickou výzvu. Standardem, který by mohl v budoucnu usnadnit propojení AI s elektronickými zdravotními záznamy a informačními systémy, je HL7/FHIR, umožňující jednotný a bezpečný přenos zdravotnických dat mezi různými systémy (9).

Konkrétní podoba takové integrace a další vývoj regulací teprve ukáží směr, jakým se využívání AI v primární péči bude v Česku ubírat. Podoba ambulantních informačních softwarů, jejich praktičnost a uživatelsky přívětivé rozhraní s důrazem na konkrétní klinickou praxi se odvíjí od potřeb ambulantních lékařů. Proto bychom neměli čekat, ale aktivně diskutovat a apelovat na vývojáře a IT specialisty s cílem prosadit způsob využití AI v ambulantním sektoru dle našich specifických potřeb.

Regulační rámec využívání AI v klinické praxi v ČR

To, v čem Evropa vyniká ve srovnání s Amerikou a Asií z hlediska umělé inteligence, je její regulace a důraz na bezpečnost. Využívání umělé inteligence v klinické medicíně, zejména v případech, že má diagnostický nebo terapeutický význam je v současnosti jedno z nejdiskutovanějších témat v kontextu bezpečnosti AI a v České republice podléhá evropskému nařízení Medical Device Regulation (MDR) 2017/745. Podle tohoto nařízení se software, který poskytuje informace sloužící k rozhodování o diagnóze nebo léčbě, klasifikuje jako zdravotnický prostředek třídy IIa a vyšší (pokud jde o závažnost následků) s povinností posouzení shody, klinické validity, vigilance a hlášení nežádoucích příhod (10). LLM, jakým je ChatGPT, dosud nejsou certifikovány jako zdravotnické prostředky a nemají posouzení shody, jeho tvůrce OpenAI oficiálně uvádí, že nejsou určeny k lékařským účelům (11). Za jakékoli klinické využití výstupů takového softwaru nese plnou právní odpovědnost ošetřující lékař, podobně jako použití anonymního zdroje na internetu. V interakci s LLM v našich ambulancích je nutné chránit citlivé a identifikační údaje, jako jsou rodná čísla, jména, příjmení, ale i variabilní symboly (čísla dokumentů), adresy a další lokalizační údaje a v neposlední řadě také biometrická data (kam patří hypoteticky i EKG či RTG snímek, kterými by šlo konkrétně identifikovat danou osobu). Zejména dbát zvláštní obezřetnosti při využití skenovaných nebo fotografovaných dokumentů, u nichž hrozí zvýšené riziko nechtěného úniku těchto dat. Výstupy generované LLM je pak vždy nutné kriticky ověřovat a posuzovat s ohledem na bezpečnost pacientů a připravit se nést plnou právní zodpovědnost.

Poskytovatelé služeb musí dále respektovat i související právní požadavky, zejména GDPR (General Data Protection Regulation) z nařízení Evropské unie 2016/679, zákon o zpracování osobních údajů (č. 110/2019 Sb.), zákon o kybernetické bezpečnosti (č. 181/2014 Sb.), zákon o elektronizaci zdravotnictví (č. 325/2021 Sb.), zákon o zdravotnických prostředcích a diagnostických zdravotnických prostředcích in vitro (č. 375/2022 Sb.). Důraz Ministerstva zdravotnictví České republiky (MZČR) v aktuálním metodickém pokynu pro poskytovatele zdravotních služeb k využívání

umělé inteligence (Věstník 9/2025) je kladen na transparentnost, lidský dohled, ochranu citlivých dat, kritické ověřování výstupů a auditní dohled, respektive důkladnou dokumentaci použití AI systémů v našich ambulancích (12). Je jisté, že další směr AI ovlivní budoucí regulace a nařízení jako třeba nařízení EU 2024/1689 známé jako Artificial Intelligence Act (AI Act), který bude vysoce rizikové AI systémy (diagnostický software a taky GPT systémy jako jsou LLM) definovat, klasifikovat a monitorovat se závaznou platností od 2. 8. 2027. V České republice se na zavádění a aplikaci právních rámců pro AI ve zdravotnictví podílí Výbor pro umělou inteligenci ve zdravotnictví (zřízený pod MZČR) a odborná platforma ČSAIM (Česká společnost pro umělou inteligenci a inovativní digitální technologie v medicíně), která propojuje lékaře, technické experty i regulátory.

Přínos AI pro primární péči

Český zdravotní systém čelí rostoucímu nedostatku praktických lékařů a sester, přičemž zhruba milion lidí zde nemá registrujícího praktického lékaře. Populace stárne, čeká nás nárůst chronických onemocnění i zvyšující se náklady na léčbu. Prohlubují se regionální rozdíly v dostupnosti péče a vysoká administrativní zátěž omezuje čas věnovaný pacientům. Česká republika patří mezi země s nejvyšším počtem kontaktů praktického lékaře s pacientem za rok. Umělá inteligence, pokud bude využita odpovědně, může pomoci zvýšit efektivitu, snížit zátěž lékařů a přispět k udržitelnosti systému. Integrace AI představuje významný krok ke zvýšení efektivitu a přesnosti klinického rozhodování (13). Redukce dimenzionality umožňuje rychlejší zpracování dat, zatímco LLM i jiné nástroje AI v reálném čase mohou amplifikovat dovednosti lékaře, zpřesnit evaluaci potíží pacienta a tím podpořit diagnostiku (14). Z praktického hlediska však nutnost klinického úsudku zůstává nepostradatelná. Je zřejmé, že AI nemůže nahradit osobnost, osobní zkušenost ani intuici lékaře. V budoucnu může správně integrovaná AI snížit administrativní zátěž a zlepšit kvalitu péče, ale je třeba vzít v úvahu netransparentnost vstupních dat a možné chyby či dezinformace při tréninku modelů. Je

třeba reflektovat riziko halucinací těchto systémů a zároveň ji přijmout jako daň za jejich kreativitu. Kreativita vždy zdobila medicínu prvního kontaktu. Právě praktičtí lékaři byli vždy zvyklí přizpůsobovat, improvizovat a přejímat účinné postupy napříč obory. Historie ukazuje, že jsme schopni hledat vlastní cesty, a organizace jako SVL (Společnost všeobecného lékařství) či SPL ČR (Sdružení praktických lékařů České republiky) dokládají naši schopnost inovace a profesní autonomie. Stejně tak bychom měli přistupovat i k umělé inteligenci – s opatrností, ale také s otevřeností, iniciativou a odbornou zralostí. Technologie by neměly být vnímány jako hrozba, ale jako nástroj, který v našich rukou může posílit silné stránky primární péče a těmi jsou lidská medicína, kontinuita, vztah, kontext, prevence, personalizace a dostupnost.

Závěr

Umělá inteligence, zejména prostřednictvím metod redukce dimenzionality a velkých jazykových modelů, představuje perspektivního pomocníka v primární péči s jejím širokým záběrem. Kombinace pokročilých algoritmů a klinické expertízy umožňuje zrychlit diagnostiku, optimalizovat administrativní úkony a přispět ke kvalitnějšímu rozhodování. Další výzkum a pečlivá validace jsou klíčové pro bezpečnou implementaci AI technologií do každodenní praxe (15). Jako praktický lékař vnímám potenciál umělé inteligence nikoliv jako náhradu, ale jako nástroj k rozšíření našich schopností tam, kde docházejí čas, kapacita či systémová podpora. AI může pomoci, ale nikdy by neměla řídit péči bez lékařova úsudku. Neustále roste tlak na rozhodování v časové tísní, a právě zde vidím prostor pro technologie, které umí rychle zpracovat data, navrhnout možnosti, upozornit na nesrovnalosti. Zavádění těchto nástrojů by však mělo vycházet především přímo z reálných potřeb klinické praxe, tedy od nás, lékařů v terénu. Máme-li z AI získat reálný užitek, musíme se jejího zavádění do praxe aktivně účastnit, kriticky ji testovat a přizpůsobovat našim podmínkám. Jen tak zůstane medicína skutečně osobní a zároveň moderní.

PROHLÁŠENÍ AUTORŮ: Prohlášení o původnosti: Publikace byla zpracována s využitím uvedené literatury a nebyla publikována ani zaslána k recenznímu řízení do jiného média. **Střet zájmů:** Žádný. **Financování:** Ne. **Poděkování:** N/A. **Registrace v databázích:** N/A. **Projednání etikou komisí:** N/A.

LITERATURA

- Lee P, Goldberg HS, Kohane IS. Integrating artificial intelligence into primary care: perspectives, challenges, and opportunities. *NPJ Digit Med*. 2023;6(1):45.
- Silver D, Schrittwieser J, Simonyan K, et al. Mastering the game of Go without human knowledge. *Nature*. 2017;550(7676):354-359.
- Mikolov T, Sutskever I, Chen K, Corrado GS, Dean J. Efficient Estimation of Word Representations in Vector Space. *arXiv preprint*. 2013; arXiv:1301.3781.
- Friston K. The free-energy principle: a unified brain theory? *Nat Rev Neurosci*. 2010;11(2):127-138.
- Beam AL, Kohane IS. Big Data and Machine Learning in Health Care. *JAMA*. 2018;319(13):1317-1318.
- Goh E, Gallo R, Hom J, et al. Large Language Model Influence on Diagnostic Reasoning: A Randomized Clinical Trial. *JAMA Netw Open*. 2024;7(10):e2440969.
- Mahale N. GPT-4.5 vs GPT-4o: Testing The AI Models Using Seven Prompts. *Writesonic Blog*. 2025 Mar 11. Dostupné z: <https://writesonic.com/blog/gpt-4-5-vs-gpt-4o>.
- Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022;28(1):31-38.
- HL7 Czech Republic. HL7 Czech Base & Core Implementation Guide. Version 0.3.0ballot, Continuous build. HL7 Czech Republic 2025. [cit. 20250802]. Available from: <https://build.fhir.org/ig/HL7-cz/czcore>.
- European Parliament and Council of the European Union. Regulation (EU) 2017/745 of the European Parliament and of the Council on medical devices. *Official Journal of the European Union*. 2017;60(L 117):1-175. [cit. 2024-08-02]. Available from: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32017R0745>.
- OpenAI. ChatGPT General FAQ: Is ChatGPT suitable for medical use? OpenAI Support. [cit. 2024-08-02]. Available from: <https://help.openai.com/en/articles/6783459-chatgpt-general-faq>.
- Ministerstvo zdravotnictví ČR. Metodický pokyn pro poskytovatele zdravotních služeb k využívání umělé inteligence. *Věstník Ministerstva zdravotnictví ČR*. 2025;(9):1-12. [cit. 2024-08-02]. Available from: <https://mzd.gov.cz/wp-content/uploads/2025/06/Vestnik-MZD-09-2025.pdf>.
- Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J*. 2019;6(2):94-98.
- Hannun AY, Rajpurkar P, Haghpanahi M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nat Med*. 2019;25(1):65-69.
- Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med*. 2019;25(1):24-29.